

인공신경망을 이용한 현장지반의 장래 침하량 산정

Estimates of Settlement in Field Ground Using Neural Networks

김 영 수*¹ Kim, Young-Su

정 성 관*² Jung, Sung-Gwan

이 상 웅*³ Lee, Sang-Woong

이 동 현*⁴ Lee, Dong-Hyun

Abstract

This study analyzed an application possibility of neural network to overcome problems of conventional settlement prediction. It is very important to estimate settlement in preloading method used to improve soft ground. At present, Hyperbolic method, Hoshino method and Asaoka method are used mostly in the prediction of settlement. But these methods can not predict settlement at the phase of design. On the other hand, neural networks are capable of predicting settlement through accumulated data in the phase of design and this method can be easily applied in practice. In this study Elman neural network is used to estimate future settlement.

요 지

본 연구는 기존의 침하량예측법의 단점을 극복하기 위한 방법으로 인공신경망의 적용성을 분석하였다. 연약지반을 개량하기 위해 사용되는 선행재하 공법에서 침하량의 산정은 매우 중요한 부분을 차지하는데, 현재 쌍곡선법, Hoshino 법, Asaoka 법이 침하량예측에 주로 사용되고 있다. 그러나 이들 방법들은 설계단계에서는 예측이 불가능하다는 단점을 가지고 있다. 반면 인공신경망은 축적된 자료들의 학습을 통해 설계단계에서 예측이 가능하며 비교적 용이하게 적용할 수 있다. 본 연구에서는 장래침하량을 산정하기 위하여 Elman 신경망을 사용하였다.

Keywords : Asaoka method, Elman neural network, Hoshino method, Hyperbolic method

1. 서 론

최근 국내에서는 사회간접시설의 투자확대와 함께 대규모 부지의 수요를 필요로 하는 공단, 공항, 주거단지, 도로, 항만시설 등을 조성하기 위하여 연약지반내의 대단위 매립 또는 성토 사업 등이 활발하게 진행중이며, 이러한 연약지반 개량시 연직배수재에 의한 선행재하공법이 일반적으로 많이 적용되고 있다. 이러한 선행재하공법의 적용 시 임의시점의 압밀도 및 하중제하

시기의 결정 등 합리적인 시공관리를 위해서는 보다 정확한 장래 침하량의 예측이 선행되어야 한다. 현재, 이러한 장래 침하량의 예측기법으로는 계측 결과를 바탕으로 역해석을 실시하여 설계 시 적용된 지반물성치를 재산정하거나 쌍곡선법, Hoshino 법, Asaoka 법 등의 계측결과를 이용한 장래 침하량의 추정법을 적용하여 현장관리를 하고 있는 실정이다. 하지만, 지반 물성치에 크게 의존하는 역해석기법은 지반의 불규칙적인 침하거동을 모사하기에 어려움이 있으며, 쌍곡선

*1 정회원, 경북대학교 토목공학과 교수 (Member, Prof., Dept., of Civil Engrg., Kyungpook National Univ.)
*2 정회원, 경북대학교 조경학과 교수 (Member, Prof., Dept., of Landscape Architecture, Kyungpook National Univ.)
*3 정회원, 경북대학교 토목공학과 박사후료 (Member, Ph. D. Candidate, Dept., of Civil Engrg., Kyungpook National Univ.)
*4 경북대학교 토목공학과 석사과정 (Graduate Student, Dept., of Civil Engrg., Kyungpook National Univ., lach61@yahoo.co.kr)

법, Hoshino법, Asaoka법 등은 상당기간 압밀이 진행된 시점에서 정확한 침하량의 예측이 가능하기 때문에 설계단계 및 재하초기 단계에서의 현장관리 기법으로는 불충분하다고 할 수 있다. 이에 반해 인공지능망을 이용한 예측법의 경우 예측결과 없이 장래 침하량을 예측하므로 기존의 산정법과 비교하여 예측결과가 유사하다면 그 유용성은 과거의 예측법보다 유용할 것으로 예상된다. 이에 본 연구에서는 기존의 침하량 예측방법의 단점을 극복하기 위한 방법으로 인공지능망을 이용하여 예측결과들을 학습 후 학습되지 않은 지역의 침하량을 예측하여 장래 침하량 예측을 위한 인공지능망의 적용성 및 효율성을 검증하였다.




그림 1. Elman 신경망 구조도

2. 인공지능망 이론

2.1 개요

인간의 생물학적 신경세포의 특성을 수학적 표현에 의해 모델링한 것을 인공지능망이라 한다. 인공지능망은 단순한 기능을 가진 무수한 처리소자들이 병렬로 연결된 연산구조를 가지고 있으며, 여러 분야에서 기존의 방법론으로는 해결하기 어려웠던 많은 부분들을 해석하는 새로운 기법으로 최근 들어 급격한 연구증가와 함께 다양한 인공지능망 모델이 등장하고 있다. 이러한 인공지능망의 형태는 크게 정적신경망 및 동적 신경망으로 구분할 수 있다. 특히 동적 신경망은 시간상 전 단계의 정보가 입력층으로 피드백 되어 다음단계 예측에 영향을 미치므로 시간경과에 따른 패턴의 특성변화를 학습 및 예측함에 있어 더욱 효과적이라 알려져 있다. Ellis 등(1995)은 동적 신경망의 형태 중 연속 인공지능망(Sequential Neural Network)을 이용하여 모래의 응력-변형률 거동을 예측하였으며, Jian-hua 등(1998)은 순환형 동적신경망(Recurrent Neural network)모델을 적용한 잔류토의 전단거동을 예측한바 있다. 이에 본 연구에서는 장래침하량의 예측에 있어 가장 중요한 요소인 시간에 따른 영향을 고려하기 위하여, 동적 신경망 모델 중 Elman 모델을 이용하여 학습과 예측을 수행하였다.

2.2 Elman 모델

Elman 모델(1990)은 광범위한 전 방향 네트워크와 지역적 순환 네트워크가 병합된 모델이다. 이 모델은 초기

상태부터 순환노드를 가지고 있음으로써 다층 퍼셉트론과 같은 정적신경망에 동적 특성의 첨가가 가능하게 된 것이다. 구조는 입력층, 은닉층, 순환층, 출력층으로 구성되며 각 층에는 2개의 층을 연결하는 연결강도로 이루어져 있다. 일반적으로 이 모델은 추가적인 기억뉴런과 지역적 피드백을 가진 특별한 종류의 전 방향 신경망으로 고려되어진다. Elman 모델에서의 순환노드의 자체 연결은 동적 시스템 모델링에서 매우 유용한 입력 데이터의 과거기록의 영향을 받음으로서 시간적 연속성의 예측에 큰 도움이 된다. Elman 모델의 구조도는 그림 1과 같다.

Elman 신경망 내의 뉴런들은 활성화 기억 능력의 여부에 따라 정적뉴런과 동적뉴런으로 구분된다. Elman 모델에서 은닉층은 동적 뉴런으로 구성되며, 그 외의 입력층과 출력층은 정적 뉴런으로 구성된다. 현단계 은닉층의 입력값은 식 (1)과 같이 현 단계 정적뉴런들의 가중치 합과 전 단계 동적뉴런들의 가중치 합으로 표현되고, 이 값에 활성화함수가 곱해져서 식 (2)와 같은 은닉층 출력값이 계산된다.

$$net_{jit} = \sum w_{jit} o_{pit} + \sum r_{jit} o_{pj(t-1)} + \theta_{jt} \quad (1)$$

$$o_{pit} = f_j(net_{jit}) \quad (2)$$

식 (1)에서, w_{jit} 는 정적 연결강도이며, r_{jit} 는 동적 연결강도이다. 연결강도의 변화는 역전파 신경망과 유사한 형태로 델타규칙에 의해 식 (3), (4)에 의해 산정된다.

$$\Delta_p w_{jit} = \eta \delta_{pit} o_{pit} + w_{jit(t-1)} \quad (3)$$

$$\Delta_p r_{jit} = \eta \delta_{pit} o_{pj(t-1)} + r_{jit(t-1)} \quad (4)$$

3. 기존의 침하량 예측방법

침하량 예측은 특히 기술적인 판단이 필요하며 여러 가지 방법들을 사용하여 추정하는 것이 바람직하고 실측치와 비교하여 현장과 가장 잘 일치하는 방법을 채택하는 것이 바람직하다. 실제 현장에서는 주로 압밀이론과는 관계없이 실측된 침하량을 적합한 곡선식으로 도출하여 장래침하량을 주로 예측하고 있다. 이러한 방법에는 쌍곡선법, Hoshino법, Asaoka법 등이 있다.

3.1 쌍곡선법

쌍곡선법은 시간의 경과에 따른 침하의 진행이 쌍곡선모양으로 감소한다는 가정을 기초로 경과시간과 침하량을 변수로 한 침하 곡선식을 결정하여 장래의 침하 과정을 예측하는 방법이다. 따라서 선형적인 간극수압의 분포와 양방향 배수조건 하에서의 “시간/압밀도-시간”의 관계로 도시되었을 때 압밀도 60%까지는 곡선을 보인 후 60~90%사이에서는 직선적인 관계를 나타낸다. 그러므로 이 방법을 적용하여 추정할 시에는 압밀도가 약 50%정도 도달해야만 어느 정도 근사치에 접근할 수 있는 것으로 알려져 있다.

3.2 Hoshino법

위에서 소개한 쌍곡선법은 침하의 평균속도가 시간에 대해 쌍곡선으로 변하지 않으면 그 타당성이 결여된다. 그래서 실제 현장에서 계측된 자료들을 쌍곡선법에 의해 fitting 했을 때 직선이 아닌 곡선의 모양을 보이는 경우가 종종 발생하고 있다. 이를 보완하고자 Hoshino법이 착안되었는데 쌍곡선 방법은 침하의 시간적 경과에 대해서 Terzaghi의 압밀론에 의하면 초기 침하가 시간의 평방근에 비례하나 Hoshino법은 현장에서 전단에 의한 유동변형을 포함하여 침하가 시간의 평방근에 비례한다는 기본원리에서 장래 침하량을 예측하는 방법이다. 또 이 방법은 \sqrt{t} 법이라고도 하며 순간적으로 재하할 때 t 시간 후에 발생하는 전 침하량은 재하직후에 발생하는 성토직후의 침하량과 시간에 따라 증가하는 침하량의 합으로 나타낼 수 있으며 쌍곡선법에 비해 예측치가 낮은 것으로 알려져 있다. 또 이 방법은 시간과 침하량의 선정방법에 따라 추정결과가 달라지므로 회귀분석시 직선성이 좋도록 계측결과를 수정할 필요가 있다.

3.3 Asaoka법

Asaoka는 Mikasa의 1차원적 미분방정식을 이용하여 현장 침하 자료로부터 임의의 시점에서의 침하량을 구할 수 있는 도식적 방법을 제안하였다. Asaoka는 1차원 압밀방정식에 의거 하중이 일정할 때의 침하량을 나타내는 간편식으로 식 (5)와 같은 Model식을 사용하였다.

$$S_i = \beta_0 + \beta_1 \cdot S_{i-1} \quad (5)$$

여기서, S_i : 시간 t 를 이산화하여 $t_i = t \times i (i=1, 2, 3, \dots)$

로 할 때 시간 t_i 에서의 침하량

S_{i-1} : 시간 $t_{i-1} = \Delta t \times (i-1)$ 에서의 침하량
 β_0, β_1 : 실측침하량으로 구한 계수

Asaoka 방법은 대개 압밀도 60%정도에서도 비교적 장래침하량을 잘 예측할 수 있는 것으로 알려져 있다.

4. 인공신경망의 적용 및 분석

4.1 입력값의 선정

인공신경망에 의한 침하량 예측 시 입력값의 선정과정에서 입력값의 수가 많게 되면 학습시간의 증가가 발생되지만, 많은 수의 입력값과 많은 횟수의 학습은 비선형 함수에 대한 정확한 이해를 가능하게 하여 보다 정확한 침하량 예측이 수행될 수 있다. 그러나 침하거동에 영향을 미치지 않는 학습인자를 사용하고, 중요인자를 학습에 사용하지 않는다면 영향인자와 출력값의 상호관계가 정립되지 않아 그 정확도는 현저히 떨어지게 되며, 중요인자와 영향을 미치지 않는 인자를 모두 학습에 사용한다면 학습에 소요되는 시간이 길어지게 될 것이고, 영향을 미치지 않는 인자들은 noise작용을 하게 되어 정확도의 감소와 함께 수렴속도가 현저히 저하된다. 이렇듯 신경망의 예측능력은 출력값에 영향을 미치는 적합한 입력값의 선택에 가장 큰 영향을 받는다. 본 연구에서는 침하거동 및 장래 침하량의 예측을 위해 성토체의 재하 조건으로써 재하일수(t), 성토하중(P)을 고려하였으며, 침하거동에 가장 큰 영향을 미치는 시간에 따른 성토하중의 증가량(ΔP)을 입력변수로 고려하였다. 또한 지반 고유의 압밀 특성을 나타내는 대표적인 물성값인 초기간극비(e_0), 압축지수(compression index, C_c), 압밀계수(coefficient of consolidation, c_v), 수평압

표 1. 지반물성치

구분	계측 번호	연약층 두께 (m)	e_0	c_c	c_v (cm^2/sec)	c_h/c_v	구분	계측 번호	연약층 두께 (m)	e_0	c_c	c_v (cm^2/sec)	c_h/c_v		
합 습	A	1	10.2	3.930	2.249	0.000490	학 습	C	10	11	2.223	0.853	0.000818	1.736	
		2	9.0	3.930	2.249	0.000490			11	11.3	1.798	0.891	0.000300	3.808	
		3	16.3	3.680	1.690	0.000350			12	10.4	2.773	1.559	0.000136	6.457	
		4	10.4	3.380	1.690	0.000150			13	11	2.773	0.853	0.000818	1.736	
		5	10.2	3.680	1.623	0.000350		예 측	A	14	10.4	3.380	1.69	0.000150	6.57
		6	18.4	3.680	1.216	0.000350				15	10.2	3.930	2.249	0.000490	6.57
	B	7	6.0	0.944	0.305	0.000350	5.00		C	16	23	1.183	0.331	0.000975	5.00
		8	8.5	1.704	0.542	0.000280	5.00	17		8.5	1.704	0.542	0.000280	5.00	
		9	18.5	1.632	0.647	0.000135	6.00	18		11.2	2.214	1.068	0.000208	4.185	
								19	11.3	1.798	0.891	0.0003	3.808		

밀계수와 연직 압밀계수의 비(c_h/c_v)를 고려하였다. 본 연구에 적용된 지반은 모두 정규압밀상태의 지반이기 때문에 과압밀 지반의 침하거동인자는 입력값에서 제외하였다. 이상과 같이 결정된 입력값은 다음과 같다.

[Input : Target] = [재하일수(t), 성토하중(P), 연약층 두께(H_s), ΔP , e_0 , C_c , c_v , c_h/c_v : 침하량(H)]

본 연구에서는 표 1과 같이 포항지역내 연약지반 개량시 선행재하 공법이 적용된 3개 지역의 지반물성값 및 침하량 계측결과를 이용하여 신경망의 학습 및 예측을 수행하였다.

4.2 신경망의 구조설계

신경망의 학습 및 예측능력은 은닉층 구조 및 뉴런의 학습율과 모멘텀 상수들과 같은 인자들에 의해 큰 영향을 받는다. 다층 퍼셉트론에서는 3층 이상이 되면 수렴이 보장되어 있으나 Elman 모델에서는 서로 다른 층에서의 입력으로 인해 어떤 경우에는 진동, 발산할 위험성이 있다. 이러한 문제의 해결을 위해서는 구조를 변경하여 안정성을 확보하여야 한다.

본 연구에서는 은닉층을 1개로 적용하였으며, 은닉층 뉴런의 수는 최적구조를 선정하고자 입력수의 영향을 고려하여 4가지(10, 15, 20, 30) 경우로 나누어 학습에 사용하였다. 목표 오차값의 경우 이전 연구자들은 0.01을 주로 적용하였으나, 본 연구에서는 Elman 모델의 효율성과 현재 컴퓨터의 처리속도 향상을 고려하여 0.005와 0.001을 선정하였다. 일반적으로 목표 오차값이 낮으

면 낮을수록 정확한 예측이 가능하리라 생각되어지나, 실제 각 모델의 설계형태와 입력변수에 따라 적정한 값이 정해진다. 이와 같이 최적 신경망의 설계에 있어서 학습대상과 예측목적에 따라 각 상황에 맞는 신경망의 설계가 매우 중요하다. 본 연구에서는 학습율과 모멘텀 상수는 자동적으로 초기화, 수정되는 적응적 모델을 적용하여 보다 편리하며 정확성의 확보가 가능하게 하였다. 왜냐하면 학습율과 모멘텀의 선정에 있어 사용자의 주관적 판단을 배제할 수 있으며 상황에 따라 변화하여 적용됨으로서 정확성을 가질 수 있기 때문이다. 본 연구에서는 최적신경망을 선정하기 위하여 13개 지역(계측번호 1~13)의 계측결과를 적용하여 목표 오차값(0.001, 0.005) 및 은닉뉴런의 수(10, 15, 20, 30)를 변화시켜 학습을 수행하였으며, 학습에 참여하지 않은 계측결과(계측번호 14~19)에 대해 예측을 실시한 후 실측치와 비교하여 예측결정계수(R-square)가 가장 높은 경우를 최적신경망 구조로 선정하였다. 표 2는 최적 신경망 구조를 선정하기 위한 예측결정계수를 나타낸 것으로 은닉층의 구조 및 목표오차값에 따라 최고 94.11%에서 최저 73.06%까지 다양하게 변화됨을 알수 있다. 이렇듯 신경망의 예측능력은 신경망의 구조에 아주 민감하게 반응하는 반면, 최적구조를 선정하기 위해서는 시행착오를 통한 구조선정 외에는 현재까지 별다른 대안이 없다는 것이 신경망 적용의 단점이라 사료된다. 은닉층의 구조 및 목표오차값에 따른 예측결정계수는 목표 오차값이 0.005, 은닉뉴런의 개수는 10개인 경우에 가장 높게 나타났다.

표 2. 예측결정계수

은닉층수	목표오차값	예측결정계수 (%)						평균
		A-14	A-15	B-16	B-17	C-18	C-19	
10	0.005	87.50	89.70	95.30	96.25	98.00	97.94	94.12
	0.001	69.81	92.40	35.66	93.95	50.82	99.72	73.73
15	0.005	84.93	91.99	23.28	94.84	88.12	97.80	80.10
	0.001	95.12	61.88	55.65	95.57	79.95	97.99	81.03
20	0.005	88.07	94.16	47.08	95.53	85.52	98.15	84.75
	0.001	97.32	32.03	84.44	89.49	75.52	99.38	79.70
30	0.005	80.24	57.26	98.27	96.81	97.91	98.21	88.12
	0.001	94.72	28.53	60.70	90.00	64.88	99.52	73.06

4.3 학습 및 예측결과 분석

4.3.1 침하거동 예측결과

선정된 최적신경망 구조를 적용하여 학습을 실시한 후 A, B, C지역의 침하거동을 예측한 결과는 그림 2와 같다. A지역(No. 14, 15)의 경우 학습에 관여한 지점이 6곳으로 다른 두 지역(B지역-3, C지역-4) 보다 많음에도 불구하고 예측결정계수가 가장 낮게 나타났다. A-14 지점의 경우, 전체적인 침하거동은 예측결과와 유사하나 동일시점에서 침하량을 다소 과대 평가하는 것으로 나

타났으며, A-15지점의 경우는 전반적으로 침하량을 과소 평가하는 것으로 나타났다. B-16, 17 지점은 예측결정계수가 0.95 이상으로 전반적인 침하거동은 예측결과와 유사하나, B-17지점의 경우 대략 700일 이후부터는 침하량을 과소평가 하는 것으로 나타났다. C-18, 19 지점은 예측결정계수가 0.98정도로 나타나 실제 침하양상을 잘 반영하고 있으나, C-18 지점은 성토 후 400일 경과시점에서부터 점차 침하량이 실제보다 과소 평가되고 있다. 이렇듯 신경망에 의한 예측결과가 지역별로 편차가 크게 나타난 이유는 기존의 실내시험결과를 이용

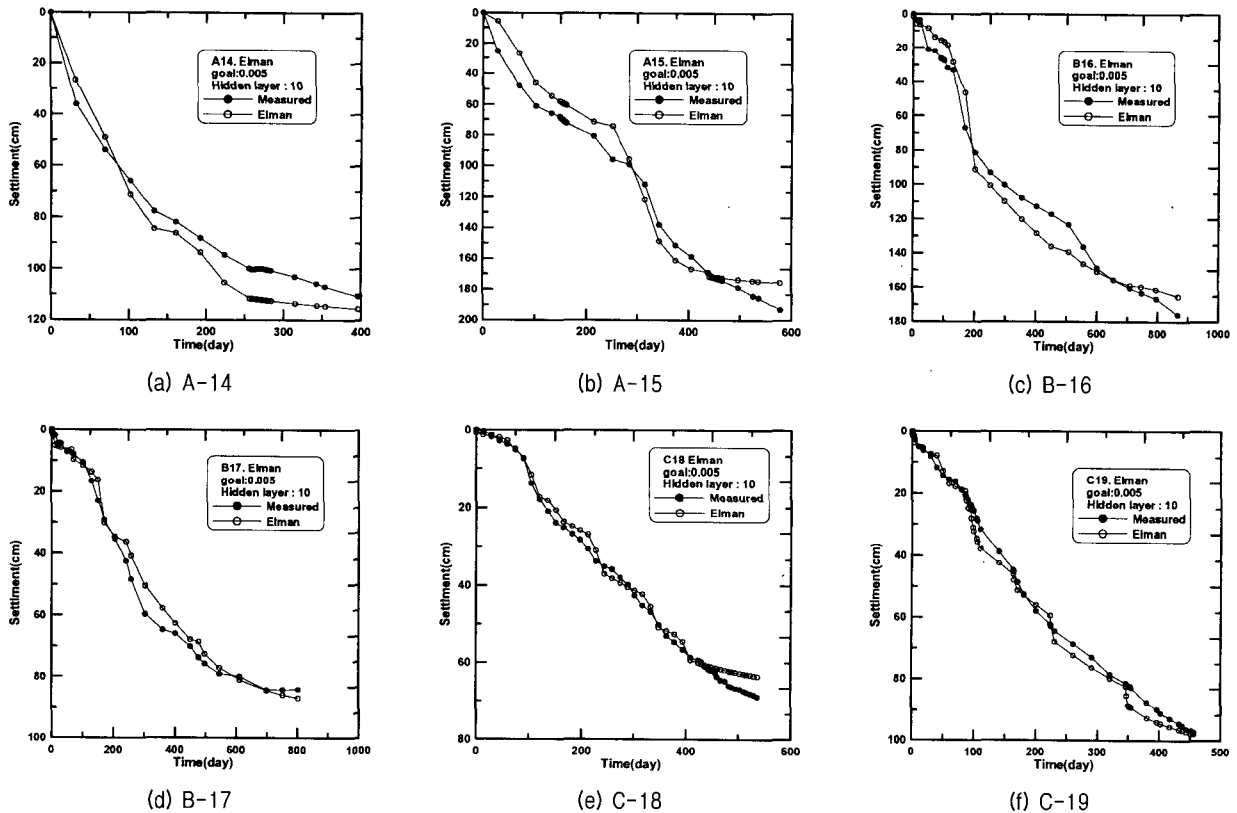


그림 2. 침하량 예측결과

한 신경망의 적용결과들과는 달리 본 연구에서는 현장의 시험결과들을 적용함으로써 정확한 지반물성값의 평가가 이루어지지 못했으며, 현장계측결과에 포함된 계측오차 등을 제대로 선별하지 못하였기 때문에 사료된다.

4.3.2 장래침하량 예측결과

인공신경망(Elman 모델)을 이용한 장래 침하량의 예측가능성을 평가하기 위하여 계측결과를 이용한 장래 침하량 추정방법들(쌍곡선법, Hoshino법, Asaoka법)에 의한 예측결과와 상호 비교하였다. 각 방법에 의한 최종 침하량의 예측결과는 그림 3 및 표 3과 같다. 각 방법을

적용한 결과 Hoshino 방법은 A-14 지점만 적용 가능하였으며, B-16 지점의 경우는 최종 성토 후 계측결과가 부족하여 기존의 3가지 예측법 모두 적용이 불가능하였다. 장래 침하량의 예측결과를 살펴보면 A-14 지점의 경우 Hoshino 법, B-17 지점의 경우는 쌍곡선법에 의한 예측결과가 현재의 계측침하량보다 과소 평가되고 있다. 이러한 예측결과는 해석방법의 본질적인 문제로서 데이터의 부족과 계측시 오류 등으로 계측데이터의 변화량이 일률적이지 못하여 전체적인 기울기 선정에서 문제가 발생한 것으로 사료된다. 그러나 Elman모델의 경우 침하양상은 물론 최종침하량 예측 역시 무리 없이 실시된 것으로 판단된다. A-15, C-18 지점의 Elman모델

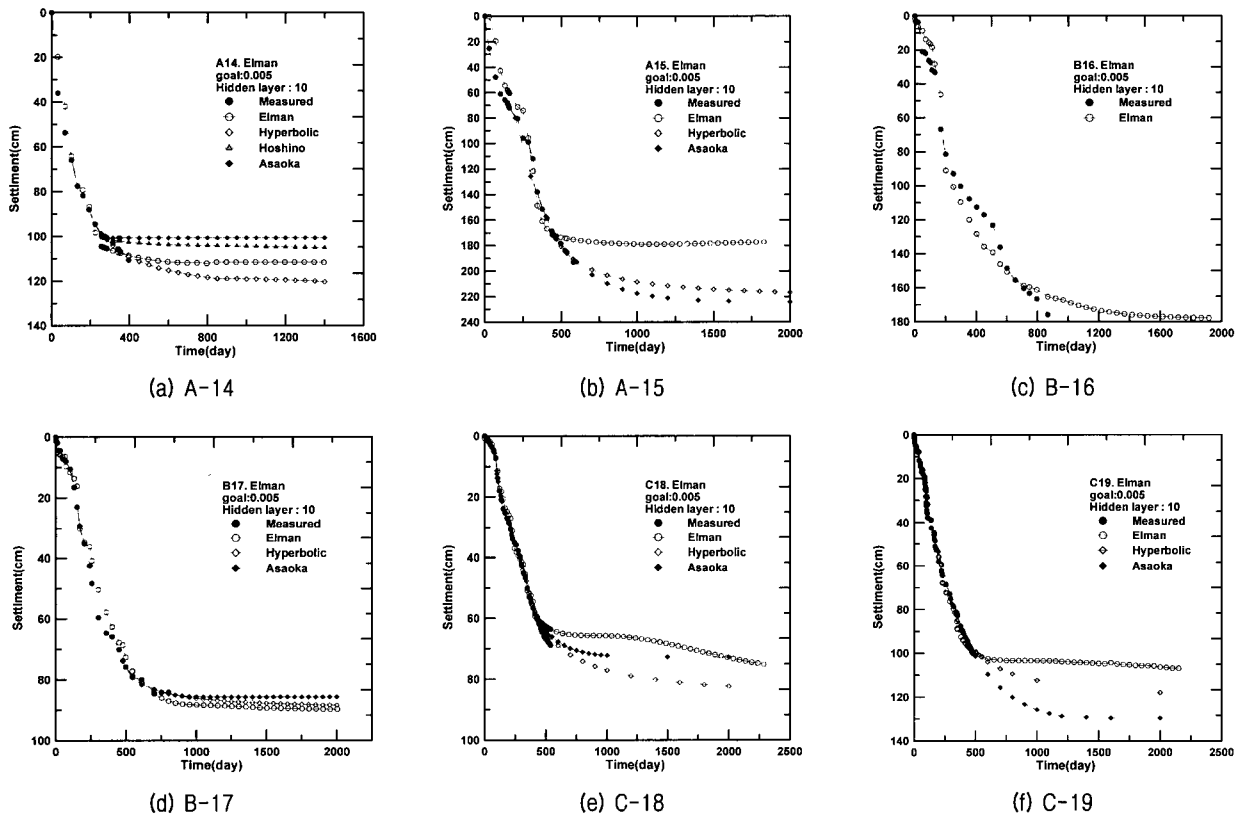


그림 3. 장래침하량 예측결과

표 3. 최종침하량 예측결과

예측지점		장래침하량 예측결과(cm)			
		쌍곡선법	Hoshino법	Asaoka법	Elman모델
A	14	120.37	105.19	100.82	113.36
	15	216.73	-	224.11	179.06
B	16	-	-	-	177.89
	17	90.02	-	85.68	89.72
C	18	82.36	-	72.76	75.14
	19	117.90	-	129.58	106.87

에 의한 장래 침하량의 예측결과 또한 현재의 계측침하량보다 예측침하량이 과소 평가되고 있다. 이러한 예측 결과는 현장에서의 침하가 계속 진행되고 있는 상태이기 때문에 학습에 관여한 자료들이 최종 침하거동을 적절히 모사하지 못하였기 때문으로 사료된다. 최종 침하량의 실제 계측값이 없는 관계로 4가지 방법에 의한 정확한 신뢰성의 평가는 어려우나 4가지 방법에 의한 예측값을 상호 비교 분석함으로써 예측의 적용 가능성은 평가할 수 있을 것으로 사료된다. 표 3의 각 방법별 예측결과를 비교한 결과 동일지점에 대한 쌍곡선법과 Asaoka법의 예측침하량의 차이는 최대 19.55cm, 최소 4.3cm로 나타났으며, 평균 10.51cm의 차이를 나타내었다. 현재의 침하량보다 장래침하량을 과소 평가한 A-15 및 비교가 불가능한 B-16 지점을 제외한 나머지 지점에 대하여 Elman 모델과 쌍곡선법에 의한 예측침하량을 비교한 결과 최대 11.04cm, 최소 0.30cm, 평균 6.80cm의 차이를 나타내었고, Elman 모델과 Asaoka법에 의한 예측침하량을 비교한 결과 최대 22.72cm, 최소 2.38cm, 평균 10.42cm의 차이를 나타내었다. 이상과 같이 Elman 모델에 의한 예측결과가 기존의 장래침하량 추정방법들 간의 오차범위 이내로 나타나 충분한 계측결과를 자료화하여 학습을 수행함으로써 향후 장래침하량의 예측 기법으로 적용 가능하리라 사료된다.

5. 결론

현장 계측결과로부터 인공신경망을 이용한 장래침하량의 예측가능성을 평가하기 위하여 Elman모델을 이용하여 학습 및 예측을 수행한 결과 다음과 같은 결론을 얻었다.

- (1) 장래침하량 예측을 위한 최적 신경망 구조의 결정 시 Elman모델을 이용하여 목표 오차값 및 은닉뉴런의 수를 변화시켜 학습 및 예측을 수행한 결과 목표 오차값이 0.005, 은닉뉴런의 개수는 10개인 경우에 예측결정계수가 가장 높게 나타났다.
- (2) 선정된 최적신경망 구조를 적용하여 A, B, C지역의

침하량을 예측한 결과 지역별 예측능력이 상이하게 나타났다. 이는 기존의 실내시험결과를 이용한 신경망의 적용결과들과는 달리 본 연구에서는 현장의 시험결과들을 적용함으로써 정확한 지반 물성치의 평가가 이루어지지 못했으며, 현장계측결과에 포함된 계측오차 등을 제대로 선별하지 못하였기 때문으로 사료된다.

- (3) Elman모델을 이용하여 장래침하량을 예측한 결과값이 기존의 장래침하량 추정방법들간의 오차범위 이내로 나타나 충분한 계측결과를 자료화하여 학습을 수행함으로써 향후 장래침하량의 예측기법으로 적용 가능하리라 사료된다.
- (4) 본 연구에서도 나타났듯이 신경망의 예측능력은 신경망의 구조에 아주 민감하게 반응하는 반면, 최적 구조를 선정하기 위해서는 시행착오를 통한 구조선정 외에는 현재까지 별다른 대안이 없다는 것이 신경망 적용의 단점으로 향후 지속적인 연구를 통해 개선되어야 할 것으로 사료된다.

참 고 문 헌

1. Ellis, G.W., Yao, C., and Zhao, R.(1992), "Neural Network modeling of the mechanical behavior of sand", *Proc., 9th Conf., ASCE Engrg. Mech.*, ASCE, New York, N.Y., 421-424.
2. Giles, C.L., Kuhn, G.M. and Williams, R.J.(1994), "Dynamic recurrent neural networks : theory and application", *IEEE Trans. Neural Network*, 5(2), 153-160.
3. G.W. Ellis, C. Yao, R. Zhao and D. Penumadu, "Stress-strain modeling of sands using artificial neural networks", *J. Geotech. Engrg. Div. ASCE*, 121(5), 429-435(1995).
4. Jeffery, L, Elman.(1990), "Finding structure in time", *Cognitive* 14, pp.179-211.
5. Jian-hua Z. and Musharraf M., Scott A.(1998), "Modeling of shearing behaviour of a residual soil with recurrent neural network", *Int. J. Numer. Anal. Meth. Geomech.*, 22, pp.671-687.
6. Parlos, A.G., Chong, K.T and Atiya, A.F.(1994), "Application of the recurrent multilayer perceptron in modeling complex process dynamics", *IEEE Trans. Neural Networks*, 5(2), 255-285.
7. Peumadu, D., Zhao R., Yao, C. and Ellis, G. W.(1995), "Stress-strain modeling of sands using artificial neural network", *J. Geotech. Engrg.*, ASCE, 121(5), pp.429-435.
8. Toll, D.(1996), "Artificial Intelligence Applications in Geotechnical Engineering", *Electronic Journal of Geotechnical Engineering*.

(접수일자 2002. 12. 26, 심사완료일 2003. 8. 20)